

Localización de Mini Vehículos Aéreos usando Sensores Inalámbricos: Un Nuevo Enfoque Experimental

J. L. Rullán Lara[†], G. Sanahuja[§], R. Lozano[§], J. Ruz Hernández[†], R. García Hernández[†]

[†]Facultad de Ingeniería–Universidad Autónoma del Carmen (UNACAR)
C. 56 No. 4 Esq. Avenida Concordia, Col. Benito Juárez, CP 24180, Ciudad del Carmen, México
{jrullan,jruz,rghernandez@pampano.unacar.mx}

[§]Heudiasyc UMR CNRS 6599, Université de Technologie de Compiègne B.P. 20529 60205, Compiègne, France
{gsanahuj,rlozano@hds.utc.fr}

Resumen—En este trabajo se presenta un análisis comparativo en tiempo real de cuatro métodos de localización aplicados a un mini vehículo aéreo no tripulado (UAV) del tipo quadrirotor¹. Mediciones de distancias de una red de sensores inalámbricos (WSN) basada en el protocolo de comunicación *Chirp Spread Spectrum* (CSS) son utilizados como proceso observado. Los desempeños de los métodos de trilateración y mínimos cuadrados son comparados con el desempeño de la estimación usando el filtro de Kalman. Los métodos de localización son implementados en tiempo real en un sistema embarcado del quadrirotor. Los algoritmos son comparados para pruebas de vuelo estacionario

Palabras clave: Filtro de Kalman, mínimos cuadrados, trilateración, localización, UAV, WSN

I. INTRODUCCIÓN

Los vehículos aéreos no tripulados (UAV) han ganado terreno en diferentes áreas civiles e industriales. Gracias a su versatilidad y talla, los aviones de este tipo pueden utilizarse en aplicaciones de supervisión (tuberías, líneas de alto voltaje, etc.) o de seguimiento de otro tipo de robots e incluso de animales. Para poder consumir dichas aplicaciones, existen dos tareas importantes a realizar. Por un lado, la estabilización de la orientación del vehículo es imperativa; por otro lado, la localización del vehículo en el medio donde se desenvuelve.

La estabilización ha sido abordada y estudiada usando diferentes enfoques lineales y no lineales. Para su aplicación en tiempo real, la técnica de backstepping (Rondon, 2010) y la técnica de saturaciones anidadas y separadas (Sanahuja, 2010; Sanahuja et. al., 2010) han demostrado un desempeño adecuado y su fácil implementación en computador numérico.

En cuanto a la localización, aún es un tema abierto que ha captado la atención de manera importante durante los últimos años. La complejidad de la localización depende del tipo de aplicación (*interior* o *exterior*), del tipo de sensor

utilizado para la captura de la información del medio y del método matemático utilizado para la estimación de la posición.

Para las aplicaciones al *exterior*, el GPS permite localizar los objetos en la superficie de la tierra con errores relativamente bajos (3-10 metros). Este desempeño es aceptable cuando se trata de robots de gran talla (automóviles, tractores, etc.) o de robots de dinámica lenta. Sin embargo, para vehículos no tripulados como los UAV los errores de posicionamiento del GPS son muy grandes en comparación a la talla de un quadrirotor que es de aproximadamente 0.8 m × 0.8 m. Otra desventaja del GPS es la necesidad de tener siempre una línea de visión (Light-Of-Sight) entre el receptor GPS y la red de satélites que giran alrededor de la tierra. Para mitigar este problema, algunos autores han combinado las mediciones GPS con mediciones de centrales inerciales (Wendel et. al., 2006), (Bristeau et. al., 2010), (Kim et. al., 2003).

Para la localización de quadrirotors al *interior*, la visión artificial ha sido explotada. Sin embargo, los principales inconvenientes radican en el alcance limitado, ya que la localización es posible sólo si el objeto (UAV) se encuentra en el campo de visión de la cámara. Por otra parte, los algoritmos de visión demandan muchos recursos computacionales, los cuales no están siempre disponibles. Algunos sistemas de visión, como *VICON Motion Capture System*, pueden encontrarse en el mercado a costos muy elevados con cámaras de alta resolución y sistema de procesamiento dedicado que realizan la estimación absoluta de un objeto con respecto a un sistema de coordenadas predefinido. Para hacer frente al inconveniente de costo, algunos autores han optado por utilizar cámaras de menor resolución y calcular la posición relativa del centro de gravedad del UAV con respecto del suelo o de un obstáculo (Angeletti et. al., 2008), (Tournier et. al., 2006). En todos los casos anteriormente mencionados, el cálculo de la posición se realiza fuera del

¹Llámeselo quadrirotor a un helicóptero con cuatro motores

vehículo.

Actualmente, una solución adecuada para hacer frente al problema de localización, son las redes de sensores inalámbricos (WSN, Wireless Sensor Networks). Este tipo de sensores son capaces de medir alguno de los parámetros de las señales de radio como la magnitud de la señal (RSS), el ángulo de llegada (AOA), el tiempo de llegada (TOA) y la diferencia de tiempo de llegada (TDOA). Además, las WSNs tiene la ventaja de poder usarse al interior como al exterior.

En esta directiva, el protocolo de comunicación basado en la tecnología CSS (*Chirp Spread Spectrum*) ha mostrado dominar el mercado de la localización en interiores (Nanotron Technologies, 2006; De Nardis y Di Benedetto, 2007). La clave de este desempeño radica en la técnica de medición del tiempo de vuelo *Symmetric Double Side Two Way Ranging* (SDS-TWR) (Nanotron Technologies, 2006; Ahn et. al, 2008). Ésta consiste en la medición del tiempo de vuelo dos veces, una vez en cada nodo. En cada medición, los nodos intercambian su rol de emisor y receptor. La tecnología SDS-TWR ha demostrado una superioridad sobre otras técnicas debido a que no requiere de la sincronización entre los relojes (un requisito importante) de los nodos.

Por otro lado, diferentes algoritmos de localización han sido propuestos, sin embargo, básicamente los mínimos cuadrados (LS) y el filtro de Kalman (KF) y versiones modificadas de ellos, han sido utilizados en diferentes aplicaciones (Torrieri, 1984; Mao et. al., 2007; Seco et. al., 2009). Más aún, basados en las mediciones de distancias, en (Doğançay y Hashemi-Sakhtsari, 2005) los autores han probado, mediante simulaciones, una forma ponderada y condicionada de mínimos cuadrados (CWLS). En (Huang et. al, 2001; Cheung et. al, 2006), basados en un modelo matemático obtenido por el método de interpolación esférica (Smith y Abel, 1987; Chan y Ho, 1994), los autores muestran una solución analítica derivada de los mínimos cuadrados con corrección de segundo grado (QCLS) y con corrección lineal (LCLS), respectivamente.

En (Yim et. al., 2008; Yim et. al., 2010) los autores proponen el seguimiento de equipos informáticos mientras que la localización de animales es propuesta por (Tøgersen et. al., 2010). Basados en la técnica CSS, la localización de un nodo inalámbrico estático se realiza en (Cho et. al., 2010) proponiendo una mejora práctica en la etapa de estimación del filtro de Kalman. Otra aplicación para la localización de los montacargas y paletas en almacenes se propone en (Röhrig y Spieker, 2008a; Röhrig y Spieker, 2008b).

El problema atacado en este trabajo es la estimación de la posición y de la velocidad lineal de un vehículo aéreo no tripulado de tipo quadrirotor usando la técnica de SDS-TWR (?). La originalidad de este trabajo radica en el hecho de que propone una solución alternativa al problema de posicionamiento de UAVs usando una tecnología que no ha sido utilizada. Las estimaciones son obtenidas en tiempo real durante experimentos de vuelo estacionario.

II. PLANTEAMIENTO DEL PROBLEMA

El problema de localización puede definirse como el proceso de encontrar la posición desconocida de un nodo a partir de la información proveniente de otros nodos que se han colocado previamente en posiciones precisas y conocidas. Por nodo nos referimos a un dispositivo que pueda medir alguna de las características o parámetros de la geografía del medio donde todos los nodos han sido colocados (normalmente una red de sensores inalámbricos). Esencialmente, localizar es un proceso de dos etapas: 1) medir la información geográfica y 2) calcular la posición desconocida usando la información previamente adquirida. Estas dos etapas han impuesto verdaderos desafíos tecnológicos y teóricos. Se trata de dos líneas de investigación que han atraído la atención desde hace muchos años en diversas áreas científicas.

El problema de localización puede plantearse matemáticamente de la siguiente manera: un conjunto de N nodos inalámbricos, llamados estaciones base (EB) (anchors, en ingles) son colocados en el plano XY en las posiciones conocidas $\mathbf{x}_i = (x_i, y_i)$, $i = 1, 2, \dots, N$ (ver figura 1). Dentro del área delimitada por las estaciones base, un nodo (objetivo) se ubica en la posición desconocida $\mathbf{p} = (x, y)$. La relación entre las variables medibles y la posición desconocida pueden, en general, ser escritas de la forma (Torrieri, 1984):

$$d_i = \sqrt{(x - x_i)^2 + (y - y_i)^2}, \quad i = 1, 2, \dots, N \quad (1)$$

donde N es el numero total de estaciones base. La distancia

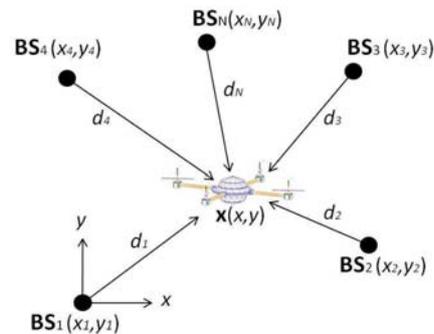


Figura 1. Problema de localizacion

d_i esta relacionada con el tiempo de vuelo de la señal de radio a través de la expresión $t_i = \frac{d_i}{c}$ con $i = 1, 2, \dots, N$ y c es la velocidad de propagación de la onda de radio.

En presencia de perturbaciones, las distancias $r_{TOA,i}$ medidas a partir de los tiempos de vuelo son modeladas como

$$r_{TOA,i} = d_i + n_{TOA,i} \quad (2)$$

donde $n_{TOA,i}$ representa el ruido en la señal.

El objetivo de los algoritmos de localización es de encontrar las coordenadas más próximas a la posición real

del vehículo aéreo. Dicha posición debe ser obtenida a partir de conjunto de ecuaciones (1)-(2) obtenidas a partir de las mediciones de la diferencia del tiempo de vuelo y la geometría del conjunto de estaciones de base. Es importante resaltar que si el número de estaciones base aumenta, la ecuación (1) es sobredeterminada. Muchos enfoques han sido propuestos para este tipo de sistema de ecuaciones.

En (Huang et. al, 2001; Cheung et. al, 2006), los autores proponen mejoras al enfoque de localización por mínimos cuadrados usando *multiplicadores de Lagrange*. En ambos casos, un factor de corrección se añade a la solución estándar de mínimos cuadrados. (Cheung et. al, 2006) propone y valida su algoritmo con simulaciones para localización basado en mediciones RSS, TOA, TDOA y AOA de la señal de radio. (Huang et. al, 2001) valida su algoritmo con datos reales y aplicándolo a la localización de una fuente sonora inmóvil.

En el caso lineal gaussiano, el filtro de Kalman tiene la ventaja de un cálculo computacional bajo debido a que solamente los dos primeros momentos de la distribución de probabilidad necesitan almacenarse (Bar-Shalom, 2001). En las aplicaciones en tiempo real, como el caso de los vehículos aéreos, terrestres y submarinos no tripulados, el tiempo de cálculo es un factor importante para alcanzar las tareas propuestas. En este sentido, el filtro de Kalman es atractivo dado que hace la estimación recursiva y su implementación es fácil.

El principal inconveniente para obtener la posición del objetivo es impuesto por el ruido en la señal de radio y las condiciones de bloqueo (NLOS). Además, el quadricopter es un sistema inestable con una dinámica rápida el cual, aún en vuelo estacionario, la condición de objetivo inmóvil no puede considerarse del todo como en (Cho et. al., 2010; Röhrig y Spieker, 2008b). Entonces, la localización debe ser suficiente para al menos localizar al UAV en una vecindad aceptable de la posición real.

III. ALGORITMOS DE LOCALIZACIÓN

Para simplificar, consideramos una red de sensores inalámbricos con cuatro estaciones de base. De aquí en adelante, la estación de base BS_1 se considera como origen del plano XY .

III-A. Trilateración

Esta técnica relaciona la geometría de las estaciones de base con la posición desconocida del objetivo. En dos dimensiones, al menos tres distancias de tres estaciones base no colineales se necesitan. Considerado una distribución circular de las señales de radio, la posición es el punto de intersección de los círculos de radio d expresados por la ecuación (1). Debido al ruido presente en las mediciones, la intersección no resulta en un solo punto sino un conjunto de punto (una zona).

Definamos $R_i^2 = x_i^2 + y_i^2$ y $\rho_{1j} = d_j^2 - d_1^2$. Sin errores en las mediciones, el conjunto de ecuaciones puede obtenerse

elevando al cuadrado (1) y sustrayendo d_1 de d_i de para $i = 2, 3, 4$. Esto es

$$\underbrace{\begin{pmatrix} X_{21} & Y_{21} \\ X_{31} & Y_{31} \\ X_{41} & Y_{41} \end{pmatrix}}_{\mathbf{M}} \mathbf{p} = \frac{1}{2} \underbrace{\begin{pmatrix} R_2^2 - R_1^2 - \rho_{12} \\ R_3^2 - R_1^2 - \rho_{13} \\ R_4^2 - R_1^2 - \rho_{14} \end{pmatrix}}_{\mathbf{T}} \quad (3)$$

donde $\mathbf{p} = (x \ y)^T$, $X_{i1} = x_i - x_1$ y $Y_{i1} = y_i - y_1$. El sistema de ecuaciones en (3) es sobre determinado, sin embargo, usando el método de la pseudo inversa, podemos obtener una solución de la forma $\mathbf{p} = (\mathbf{M}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{T}$.

III-B. Mínimos cuadrados

Este método produce una solución recursiva bajo ciertas consideraciones estadísticas de las mediciones reales. Debido a las relaciones no lineales presentes en las mediciones dadas por la expresión (1), se ha demostrado que diferentes modelos matemáticos pueden ser derivados para resolver el problema de estimar la posición de un objetivo. Dependiendo la dimensión del espacio dónde se desea realizar la estimación, los modelos son conocidos como *esféricos* (3D) o *hiperbólicos* (2D) (Huang et. al, 2001; Cheung et. al, 2006). En ambos casos, el modelo se expresa de la forma

$$\tilde{g}_{i1}(\mathbf{p}) = g_{i1}(\mathbf{p}) + \omega_{i,1}, \quad i \in \{2, 3, 4\} \quad (4)$$

donde $g_{i1}(\mathbf{p})$ es la medición sin ruido, $\tilde{g}_{i1}(\mathbf{p})$ es la medición en presencia de ruido y $\omega_{i,1}$, es el ruido presente en la medición con matriz de covarianza \mathbf{R}_ϵ . El vector $g_{i1}(\mathbf{p})$ representa la diferencia de distancias medidas $g_{i1}(\mathbf{p}) = d_i - d_1$, $i \in \{2, 3, 4\}$

Debido a las no linealidades presentes en 4, la idea más simple para obtener una solución es la de linealizar este sistema de ecuaciones usando las series de Taylor. De esta forma, el conjunto de ecuaciones obtenidas puede resolverse por el criterio de mínimos cuadrados. Con el objetivo de obtener una solución recursiva, consideremos que el objetivo se encuentra un punto inicial arbitrario $\mathbf{p}_0 = (x_0, y_0)^T$ y definamos el vector $\delta = \mathbf{p} - \mathbf{p}_0$. La ecuación (4) puede ser entonces desarrollada en series de Taylor, la cual en forma matricial se escribe

$$\mathbf{G}\delta = \mathbf{b} + \mathbf{v} \quad (5)$$

donde las filas de \mathbf{G} están expresadas como $G_j = (\frac{x_1 - x}{d_1} - \frac{x_{j+1} - x}{d_{j+1}} \quad \frac{y_1 - y}{d_1} - \frac{y_{j+1} - y}{d_{j+1}})$, los elementos de \mathbf{b} como $b_j = \tilde{g}_{j+1,1} - g_{j+1,1}(\mathbf{p}_0)$ donde $j = 1, 2, 3$

El método de mínimos cuadrados busca minimizar el error $\mathbf{e}(\mathbf{p}) = \hat{\mathbf{g}}(\mathbf{p}) - \mathbf{g}(\mathbf{p})$ minimizando la función de costo $J_{MC} = \mathbf{e}(\mathbf{p})^T \mathbf{R}^{-1} \mathbf{e}(\mathbf{p})$ ponderada por la matriz inversa de covarianza del error \mathbf{R}_ϵ . Considerando que $\mathbf{G}^T \mathbf{R}^{-1} \mathbf{G}$ es una matriz no singular, entonces la solución de (5) está dada por $\hat{\delta} = (\mathbf{G}^T \mathbf{R}^{-1} \mathbf{G})^{-1} \mathbf{G}^T \mathbf{R}^{-1} \mathbf{e}(\mathbf{p})$.

Finalmente, una solución recursiva que puede implementarse en tiempo real es $\hat{\mathbf{p}}_{k+1} = (\hat{x}_k + \hat{\delta}_{x,k} \quad \hat{y}_k + \hat{\delta}_{y,k})^T$. Esta expresión depende únicamente del valor $\bar{\delta}$ obtenido en el instante de tiempo k . Ella necesita, por lo tanto, una

buena condición inicial para poder garantizar la convergencia de la estimación. Además, debido a la linealización, los errores de estimación pueden ser grandes si el objetivo se encuentra en una porción de la hipérbola lejos de dos estaciones de base.

III-C. Mínimos cuadrados ponderados (QCLS)

Una mejora al método de mínimos cuadrados fue desarrollada por (Cheung et. al, 2006) agregando un factor de corrección con el objetivo de tomar en cuenta mas información que sólo la función de error ha ser minimizada. La información adicional es obtenida gracias a la reorganización las ecuaciones no lineales en un sistema de ecuaciones lineales.

Primero, sin ruido en las mediciones la ecuación (4) puede ser rescrita, después de ciertas operaciones algebraicas, de la forma

$$\mathbf{A}\theta = \mathbf{m} \quad (6)$$

donde las expresiones de las filas de la matrix \mathbf{A} son (X_{j1}, Y_{j1}, g_{j1}) , los elementos de \mathbf{m} son $X_{j1}^2 + Y_{j1}^2 - g_{j1}^2$ y el vector $\theta = (x - x_1, y - y_1, d_1)^T$.

Notar que el conjunto de ecuaciones en (6) es lineal en el parámetro θ , gracias a la variable intermedia d_1 . En presencia de ruido en las mediciones, el método de mínimos cuadrados permite obtener la posición del objetivo minimizando la función de error $\mathbf{e}_{sp}(\theta) = \mathbf{A}\theta - \mathbf{b}$. En (Cheung et. al, 2006) se propone minimizar la función de costo $J_{QCLS} = \mathbf{e}_{sp}(\theta)^T \mathbf{Y}^{-1} \mathbf{e}_{sp}(\theta)$ sujeta a la condición cuadrática $\theta^T \Sigma \theta = 0$ con $\Sigma = \text{diag}(1, 1, -1)$. La matrix \mathbf{Y} depende de la distancia euclidiana estimada \hat{d}_1 . Usando la técnica de los multiplicadores de Lagrange, la solución a este problema se escribe como

$$\tilde{\theta} = (\mathbf{A}^T \mathbf{Y}^{-1} \mathbf{A} + \eta \Sigma)^{-1} \mathbf{A}^T \mathbf{Y}^{-1} \mathbf{b} \quad (7)$$

Así, el algoritmo estima el vector θ de manera recursiva y finalmente, la posición estimada se obtiene como $\hat{\mathbf{p}} = (\hat{\theta}_1 + x_1, \hat{\theta}_2 + y_1)^T$.

Este algoritmo supera la estimación por linealización con series de Taylor gracias al ajuste proporcionado por la condición cuadrática. Sin embargo, en términos de cálculo numérico, necesita de mayores recursos computacionales debido a la búsqueda de las raíces del polinomio de Lagrange (Cheung et. al, 2006; Chan y Ho, 1994).

III-D. Filtro de Kalman extendido (EKF)

El filtro básico considera que los modelos de transición y de observación son lineales. Debido a las no linealidades presentes en las mediciones de distancias expresadas por la ecuación (1), el filtro de Kalman extendido debe utilizarse. Cuando la entrada es cero, la evolución de los estados esta dada por las ecuaciones estocásticas

$$\vartheta_{k+1} = \mathbf{f}_k(\vartheta_k, \mathbf{w}_k) \quad (8)$$

$$\xi_k = \mathbf{h}_k(\vartheta_k, \mathbf{v}_k) \quad (9)$$

donde ϑ_k es el vector de estados en el tiempo k , ξ_k es el vector de mediciones y \mathbf{w}_k y \mathbf{v}_k son los vectores de ruido del proceso y de las mediciones, respectivamente. Se asume que \mathbf{v}_k y \mathbf{w}_k son ruidos con distribuciones gaussianas e independientes. Esto es, $\mathbf{w}_k \sim \mathcal{N}(0, \mathbf{Q})$ y $\mathbf{v}_k \sim \mathcal{N}(0, \mathbf{R})$. También se considera que el vector de estado inicial ϑ_0 es normalmente distribuido con media $\bar{\vartheta}_0$ y matriz de covarianza \mathbf{P}_0 . Las funciones $\mathbf{f}_k(\cdot)$ y $\mathbf{h}_k(\cdot)$ en las expresiones (8) y (9) son linealizadas siendo \mathbf{F}_k y \mathbf{H}_k las matrices de transición y de observación correspondientes, respectivamente. El sistema (8)-(9) se rescribe como

$$\vartheta_{k+1} = \mathbf{F}_k \vartheta_k + \mathbf{w}_k, \quad \xi_k = \mathbf{H}_k \vartheta_k + \mathbf{v}_k$$

Las etapas de predicción y de corrección del filtro de Kalman pueden ser consultadas en (Bar-Shalom, 2001).

En (9), $\mathbf{h}(\cdot)$ es la misma que en (1), sin embargo, la función $\mathbf{f}(\cdot)$ depende de la cinemática del objetivo. Si se desea obtener la posición y la velocidad de un UAV, entonces un modelo de aceleración con ruido blanco puede ser considerado. Así, $\vartheta_k = (\mathbf{p} \quad \dot{\mathbf{p}})^T$ y en consecuencia, la función de transferencia discreta, \mathbf{F}_k , con periodo de muestreo Δ , resulta en una matrix constante de 4×4

$$\mathbf{F}_k = \begin{pmatrix} 1 & 0 & \Delta & 0 \\ 0 & 1 & 0 & \Delta \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (10)$$

mientras que la matrix \mathbf{H}_k resultante es

$$\mathbf{H}_k = \begin{pmatrix} \frac{x_k - x_1}{d_1} & \frac{y_k - y_1}{d_1} & 0 & 0 \\ \frac{x_k - x_2}{d_2} & \frac{y_k - y_2}{d_2} & 0 & 0 \\ \frac{x_k - x_3}{d_3} & \frac{y_k - y_3}{d_3} & 0 & 0 \\ \frac{x_k - x_4}{d_4} & \frac{y_k - y_4}{d_4} & 0 & 0 \end{pmatrix} \quad (11)$$

Notar que todos los elementos de (11) tienen singularidades si $d_i = 0$, $i = 1, 2, 3, 4$.

IV. DESCRIPCIÓN DE LA PLATAFORMA

IV-A. El vehículo aéreo

El vehículo aéreo es el clásico mini helicóptero con cuatro motores, el quadricóptero. Tiene dos pares de hélices que giran en sentidos opuestos que se encuentran en los extremos de dos barras en forma de equis. En el centro de la equis, el sistema embebido que consta de una central inercial, el sensor de posición y la batería están colocados.

El sistema embarcado en el helicóptero está basado en la tarjeta de desarrollo IGEPv2. Este sistema medir los ángulos de Euler y las velocidades angulares (usando una central inercial 3DMGX3-25 de Microstrain) y ejecutar las leyes de control en tiempo real a 100 Hz. Además, la altura es medida con el sensor de ultrasonido SRF50 cada 50 Hz. Una descripción detallada del sistema embarcado puede encontrarse en (Rullan, 2011).

Usando esta plataforma, fue posible validar el desempeño de los algoritmos de localización descritos en la sección



Figura 2. Mini helicóptero *quadrirotor*

anterior en tiempo real (ver figura 2). La dinámica de orientación del *quadrirotor* $\ddot{\eta} = \eta = (\phi, \theta, \psi)$ es estabilizada usando un control basado en funciones de saturación y análisis de Lyapunov (Sanahuja et. al., 2010).

IV-B. La red de sensores inalámbricos

El kit de desarrollo *nanoLOC* de *Nanotron Technologies GmbH* ha sido utilizado para medir las distancias entre las estaciones base y el *quadrirotor* (?). El sistema consta de cinco tarjetas, cuatro estaciones base y un objetivo. Cada tarjeta cuenta con el transmisor-receptor *nanoLOC TRX* el cual permite la comunicación inalámbrica entre nodos usando la metodología de medición SDS-TWR.

La tarjeta objetivo es montada en el UAV y se conecta via RS232 al sistema embarcado IGEPv2. Una trama de 68 bytes es decodificada para obtener las cuatro distancias d_k^1 , d_k^2 , d_k^3 , y d_k^4 . A pesar de que las distancias son adquiridas directamente en el mini helicóptero, los aspectos prácticos y del ambiente que afectan las señales de radio no se suprimieron. La arquitectura informática ha sido desarrollada en Visual Studio C++, incluyendo todas las operaciones matriciales para cada algoritmo

V. RESULTADOS EXPERIMENTALES

El experimento se llevó a cabo considerando el UAV en vuelo estacionario sobre el punto $\mathbf{x}_{ref} = (400\text{cm}, 300\text{cm})$. Las estaciones base se colocaron en los puntos $BS_1 = (0, 0)$, $BS_2 = (800\text{cm}, 100\text{cm})$, $BS_3 = (800\text{cm}, 700\text{cm})$ y $BS_4 = (0, 600\text{cm})$. El vehiculo esta totalmente estabilizado en orientación y se lanza desde el punto \mathbf{x}_{ref} y se mantiene volando en una vecindad del punto \mathbf{x}_{ref} . Después de alrededor de un minuto, el *quadrirotor* es aterrizado en el mismo punto de despegue. Se usó un periodo de muestreo $\Delta = 0,08$ segundos.

Las condiciones iniciales para todos los métodos fueron obtenidas a partir de (3) y las matrices de covarianzas fueron inicializadas como sigue: $\mathbf{R}_\varepsilon = \sigma_{ts}^2 \times \mathbf{I}$, $\mathbf{R}_0 = \text{diag}\{830, 650, 250, 905\}\text{cm}^2$, $\mathbf{Y}_0 = \sigma_{qcls}^2 \times \mathbf{I}$. Los valores de \mathbf{R}_0 fueron identificados por experimentación y los valores para σ_{ts}^2 and σ_{qcls}^2 fueron escogidos como el promedio de la covarianza del ruido para todos los experimentos. La matriz \mathbf{R}_k del filtro de Kalman se actualiza usando el concepto de comparación de covarianzas (Mehra, 1970).

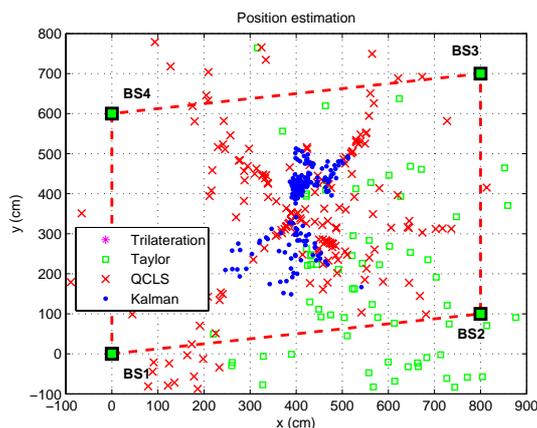


Figura 3. Posición estimada en xy

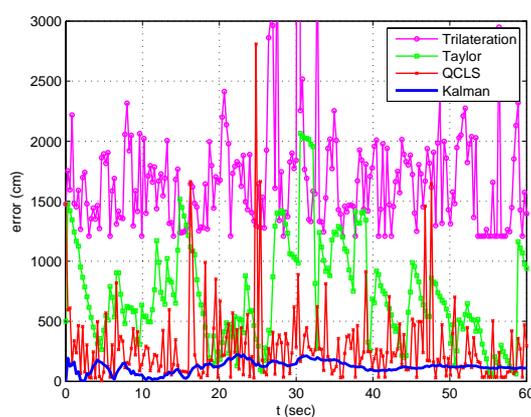


Figura 4. Error estimado

La figura 3 muestra la posición estimada cuando los algoritmos de localización son aplicados en tiempo real. La estimación por trilateración es la peor para la cual no se logran ver ninguna estimación (*) en el espacio donde el *quadrirotor* voló. En esta figura observamos que la estimación con el filtro de Kalman converge rápidamente al valor deseado. Mas aún, notar que $\hat{\mathbf{p}}_{ts}$ y $\hat{\mathbf{p}}_{qcls}$ tiene cambios repentinos en magnitud durante casi todo el tiempo mientras que la estimación con Kalman es más suave (ver figura 5). Estos valores se encuentran fuera del espacio delimitado por las cuatro estaciones base y deben mitigarse si se desean utilizar en el lazo de control de la posición del *quadrirotor*. Por el contrario, $\hat{\mathbf{x}}$ pudiera utilizarse inmediatamente. Este comportamiento suave de la estimación es importante cuando nuevos puntos del espacio de trabajo son alcanzados por el UAV. Así, le estimación podría combinarse con algún otro sensor inercial para obtener una localización más precisa. La figura 4 muestra el error obtenido de las estimaciones.

Los errores de posición se listan en la tabla I. El filtro de Kalman mejora el desempeño de los métodos basados en mínimos cuadrados con un error de posición promedio de

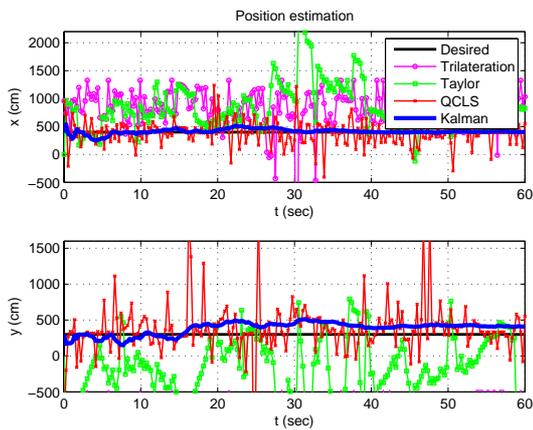


Figura 5. Estimación \hat{p} .

Debido a que las oscilaciones están presentes en las estimaciones con series de Taylor y con QCLS, estos datos fueron suavizados para mejorar los resultados. Las posiciones estimadas fueron suavizadas usando el mismo modelo cinemático que para el filtro de Kalman. De la figura 5 podemos ver cómo los datos de QCLS son bastante similares a aquellos obtenidos con el filtro de Kalman en ambas coordenadas después del suavizado. Esto significa que el método QCLS y el suavizador pueden implementarse en tiempo real y podrían usarse en el lazo de control de posición como se mencionó anteriormente. Los datos suavizados en la figura 6 reportan un MAPE de $138,53cm$ y valores promedio de $\mu_x = 391,46cm$ y $\mu_y = 410,93cm$ y desviaciones estándares de $\sigma_x = 70,171cm$ y $\sigma_y = 80,668cm$.

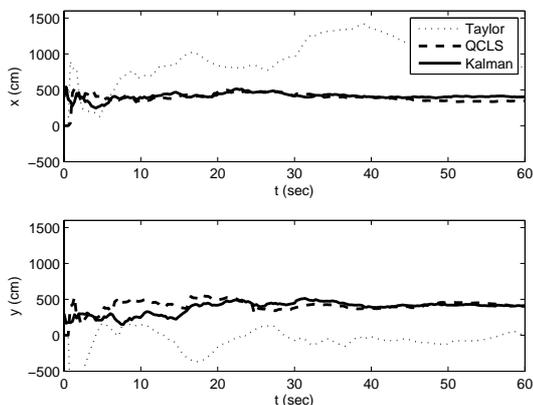


Figura 6. Estimación \hat{p} después del suavizado.

VI. CONCLUSIONES

Cuatro métodos de localización fueron comparados en tiempo real. La trilateración, dos métodos con mínimos cuadrados (series de Taylor y Quadratic-Correction Least

TABLA I
DESEMPEÑO DE LOS ALGORITMOS

Parameter (cm)	Tri.	Taylor	QCLS	Kalman
μ_x	—	825,26	387,27	411,06
μ_y	—	-161,20	368,46	383,87
σ_x	—	413,22	214,42	43,68
σ_y	—	400,83	377,01	86,367
MAEP	1694,4	729,99	286,39	119,43

Squares) y el filtro de Kalman extendido son implementados en lazo cerrado en experimentos de vuelo estacionario de un UAV. Una red de sensores inalámbricos, basada en el protocolo de comunicación *Chirp Spread Spectrum (CSS)* es utilizado para medir las distancias entre las estaciones base y el quadrirotor.

El método de la trilateración reportó el peor desempeño. Esto es un resultado esperado ya que solamente se basa en el error absoluto y por lo tanto no es exacto. De acuerdo a nuestro estudio, los algoritmos basados en los mínimos cuadrados tienen ambos un comportamiento muy similar pero QCLS reporta una mayor precisión que las series de Taylor. Sin embargo, las estimaciones con el filtro de Kalman estuvieron más cercanas a la posición real del quadrirotor que los otros tres métodos.

La matriz de covarianza del filtro de Kalman fue actualizada usando el concepto de comparación de covarianzas. Esto nos permitió obtener una estimación suave y alcanzar la posición del objetivo aún cuando la posición inicial estuviera demasiado alejada de la real. Mas aún, y de acuerdo a nuestro estudio, para la implementación en tiempo real los métodos basados en mínimos cuadrados deben mejorarse con un suavizador para evitar cambios drásticos de magnitud en las estimaciones y que las hagan diverger.

El trabajo actual está centrado en incluir el algoritmo de localización desarrollado con el filtro de Kalman en el lazo de control de la estabilización del quadrirotor y realizar seguimiento de trayectorias.

VII. AGRADECIMIENTOS

El primer autor agradece a la Universidad Autónoma del Carmen (UNACAR) y a la Secretaría de Educación Pública (SEP) por la Beca de Estudios de Posgrado de Alta Calidad PROMEP/103.5/07/2057.

REFERENCIAS

- Rondon, E. (2010) Navigation d'un véhicule aérien par flux optique, Université de Technologie de Compiègne. France.
- Sanahuja, G. (2010), Commande et localisation embarquée d'un drone aérien en utilisant la vision, Université de Technologie de Compiègne. France.
- Sanahuja, G., Castillo, P., Sanchez A. (2010). Stabilization of n integrators in cascade with bounded input with experimental application to a VTOL laboratory system. *International Journal of Robust and Nonlinear Control* **20** (10), 1129–1139
- Wendel, J., Meister, O., Schlaile, C., Trommer, G. F. (2006). An integrated GPS/MEMS-IMU navigation system for an autonomous helicopter. *Aerospace Science and Technology* **10**, 527–533

- Bristeau, P. J., Dorveaux, E., Vissière, D., Petit, N. (2010) Hardware and software architecture for state estimation on an experimental low-cost small-scaled helicopter. *Control Engineering Practice* **18**, 733–746
- Kim, J., Sukkarieh, S., Wishart, S. (2003). Real-time navigation, guidance and control of an UAV using low-cost sensors. *International Conference of Field and Service Robotics (FSR'03)*, 95–100. Yamanashi, Japan.
- Angeletti, G., Pereira-Valente, J. R., Iocchi, L., Nardi, D. (2008). Autonomous Indoor Hovering with a Quadrotor. *International Conference on Simulation, Modeling and Programming for Autonomous Robots*, 3–4 November. ISSN 978-88-95872-01-8
- Tournier, G. P., Valentini, M., How, J. P. (2006). Estimation and Control of a Quadrotor Vehicle Using Monocular Vision and Moiré Patterns. *AIAA Guidance, Navigation, and Control Conference and Exhibit*, 21–24 August, Keystone, Colorado
- Huang, Y., Benesty, J., Elko, G. W., Mersereau, R. M. (2001). Real-time passive source localization: a practical linear-correction least-squares approach. *IEEE Transactions on Speech and Audio Processing* **9** (8), 943–956.
- Cheung, K. W., So, H. C., Ma, W.-K., Chan, Y. T. (2006). A Constrained Least Squares Approach to Mobile Positioning: Algorithms and Optimality. *EURASIP Journal on Applied Signal Processing* Article ID 20858, 1–23.
- Doğançay, K., Hashemi-Sakhtsari, A. (2005). Target tracking by time difference of arrival using recursive smoothing. *Signal Processing* **85** (4), 667–679
- Bar-Shalom, Y., Li, X.-Rong, Kirubarajan, T. (2001). *Estimation with Applications to Tracking and Navigation*. John Wiley & Sons, Inc. New York, NY, USA.
- Nanotron Technologies GmbH (2006). *Real Time Localization Systems (RTLS), White paper*
- De Nardis, L. y Di Benedetto, M.-G. (2007). Overview of the IEEE 802.15.4/4a standards for low data rate Wireless Personal Data Networks. *4th Workshop on Positioning, Navigation and Communication* Hannover, Germany.
- Ahn, H.-S., Hur, H., Choi, W.-S. (2008). One-way Ranging Technique for CSS-based Indoor Localization. *IEEE International Conference on Industrial Informatics*. Daejeon, Korea.
- Torrieri, D.J. (1984). Statistical Theory of Passive Location Systems. *IEEE Transaction on Aerospace and Electronic Systems* **AES-20** (2), 183–198.
- Mao, G., Fidan, B., Anderson, B. D. O. (2007). Wireless sensor network localization techniques. *Computer Networks* **51** (10), 2529–2553.
- Seco, F., Jiménez, A., Prieto, C., Roa, J., Koutsou, K. (2009). A survey of Mathematical Methods for Indoor Localization. *IEEE 6th International Symposium on Intelligent Signal Processing*. Budapest, Hungary.
- Smith, J. O. y Abel, J. S. (1987). Closed-form least-squares location estimation from range-difference measurements. *IEEE Trans. Acoust. Speech, Signal Processing* **ASSP-35**, 1661–1669.
- Chan, Y.T. y Ho, K.C. (1994) A simple and efficient estimator for hyperbolic location. *IEEE Transaction on Signal processing*
- Yim, J., Park, C., Joo, J., Jeong, S. (2008). Extended Kalman Filter to wireless LAN based indoor positioning. *Decision Support Systems* Elsevier **45**, 960–971.
- Yim, J., Jeong, S., Gwon, K., Joo, J. (2010). Improvement of Kalman filters for WLAN based indoor tracking. *Expert Systems with Applications* Elsevier **37** (1), 426–433.
- Tøgersen, F. A., Skjøth, F., Munksgaard, L., Højsgaard, S. (2010). Wireless indoor tracking network based on Kalman filters with an applications to monitoring dairy cows. *Computer and Electronics in Agriculture* Elsevier **72**, 119–126.
- Cho, H., Lee, C. W., Ban, S. J., Kim, S. W. (2010). An enhanced positioning scheme for chirp spread spectrum ranging. *Expert Systems with Applications* **37**(8), 5728–5735.
- Röhrig, C. y Spieker, S. (2008). Localization of Pallets in Warehouses using Wireless Sensor Networks. *16th Mediterranean Conference on Control and Automation*, 1833–1838.
- Röhrig, C. y Spieker, S. (2008). Tracking of Transport Vehicles for Warehouse Management using a Wireless Sensor Network. *2008 IEEE/RSJ International Conference on Intelligent Robots and Systems*, Nice, France.
- Mehra, R. K. (1970). On the identification of variances and adaptive kalman filtering, *IEEE Trans. Autom. Control* **AC-15** (2), 175–184.
- Rullán Lara, J. L. (2011) Conception et implantation embarquée d'un système de positionnement en utilisant les signaux radio pour la stabilisation d'un minidrone, Université de Technologie de Compiègne. France.
- Röhrig, C. y Müller, M. (2009). Indoor Location Tracking in Non-line-of-Sight Environments Using a IEEE 802.15.4a Wireless Network. *IEEE/RSJ International Conference on Intelligent Robots and Systems*, 552–557.
- Röhrig, C. y Müller, M. (2009). Localization of Sensor Nodes in a Wireless Sensor Network Using the nanoLOC TRX Transceiver. *IEEE 69th Vehicular Technology Conference Spring*, Barcelona, Spain.